

신경망을 이용한 유연디스크 가공 종단부 품질예측에 관한 연구

유송민*

(논문접수일 2010. 10. 25, 심사완료일 2010. 11. 01)

A study on the exit stage quality prediction of flexible disk process
using neural network

Song Min Yoo*

Abstract

Even though a flexible disk grinding process was often applied to enhance the product quality, it produced non-flat zone in the beginning and the exit (end) area. Since latter area is susceptible to poor product quality with burn mark, careful analysis is required to cope with such degradation. The flexible disk grinding exit stage was analyzed for workpiece length, wheel speed, depth of cut and feed. The exit stage qualities defined as exit stage ratio and exit stage angle or slope was characterized. A neural network application results revealed that exit stage characteristics was predicted more accurately without workpiece dimension with minimum error of 1.3%.

Key Words : Flexible disk grinding(유연성디스크연삭가공), Exit stage(종료구간), Neural network(신경망), Stage characteristics(가공단계특성)

1. 서론

제반 산업제품의 획기적인 개발에 필수적인 기계가공기술의 발전이 날로 진보하고 있으며 최근에는 나노기반 제품에 도전하는 기술적인 비약을 달성하고 있다. 이러한 첨단기술의 대두에도 불구하고 이를 지원하기 위한 기반기술의 중요

성은 점차로 증가하고 있다. 제품의 다양화로 인하여 복합적인 가공기술이 소요되고 이에 따라 제품의 형상오차 및 표면 다듬질 수준의 중요성이 점차로 증가하고 있다. 가공물의 품질을 저하시키는 가장 큰 요인 중에 하나로 가공 후 제품에 남아있는 잔류물, 즉 버(burr)가 있으며 이를 제거하기 위하여 다양한 방법이 사용되었다. 이러한 버를 제거하기가 용이

* 경희대학교 공과대학 기계공학과 (smyoo@khu.ac.kr)
주소: 449-701 경기도 용인시 기흥구 서천동 1

하지 않기 때문에 절삭가공, 압력에 의한 제거 등의 방법이 사용되었다. 이러한 버에 대한 주요사례로 절삭가공, 전해가공 및 자기연마법 등이 있다⁽¹⁻³⁾. 이러한 버를 제거하는 디버링공정을 지원하기 위하여 정확한 버의 제원과 위치를 파악하는 것이 중요하다. 버의 측정을 가장 효과적으로 하기 위하여 디지털이미지를 이용한 화성처리 방법이 적용되었다⁽⁴⁾.

버의 이해와 함께 이를 제거하는 디버링 공정에 대한 정확한 해석이 요구되는 데, 이는 공정의 정확한 설계와 함께 제품의 품질을 보다 정확히 예측하기 때문이다. 여러 가지 디버링 공정 중에 브러시 또는 디스크를 이용한 공정에 대한 모델이 잘 알려져 있다. 브러시는 여러 가닥의 단일 브러시 요소가 사용되므로 이것이 집합적으로 나타나는 공정에 대한 해석적인 모델이 비교적 어려운 것으로 알려지고 있다. 디스크의 경우에는 이의 변형점에 대한 정확한 해석이 요구되고 있으나 브러시공정에 비하여 보다 일반적인 모델이 개발되어 활용되었다. 초기에 MIT 및 CSDL(Charles Stark Draper Laboratory)에서 로봇과 연결된 연마기에 대하여 디스크와 축간의 동역학적인 모델이 개발되었다⁽⁵⁾. 디스크 전체가 회전축에 대하여 변형사는 단순한 형태의 모델로 절삭력 등의 해석적인 유수가 가능하였다. 강체의 디스크에 비하여 유연성을 지니는 유연디스크에 대하여 디스크상에 변형이 일어나는 수정모델이 개발되어 실제의 가공물과 가공물의 형상을 비교한 결과 가공형상을 비교적 잘 예측하는 것으로 나타났다⁽⁶⁾. 기본모델에 이송속도를 변화시켜 가공물의 형상을 개선시키는 연구가 수행되었으며 이 결과로 가공물의 가공형상이 개선되었다. 단계별 특징구간을 도입한 모델을 이용하여 공정중에 비평면 구간을 최대한 확보하는 개선효과가 이루어졌다⁽⁷⁾.

유연디스크의 특성분석에 대한 연구로서 가공물의 특성을 무차원화한 변수인 평면구간길이와 공작물길이의 비율, 최저절입값과 절삭깊이비 등이 절삭속도, 절삭깊이 및 이송속도와 같은 가공조건에 대하여 분석하였다⁽⁸⁾. 인공지능 신경망은 해석적인 모델의 성립이 어려운 시스템에 적용되며 입력과 출력인자간의 연계성이 유추된다. 가공공정에 적용된 신경망시스템은 절삭칩용 브레이커의 평가, 공구의 마모 분석 및 공정인자 예측에 적용되었으며 해석모델이 없는 경우에 효과적인 것으로 나타났다⁽⁹⁻¹²⁾.

본 연구에서는 유연디스크의 해석모델을 기반으로 정의된 가공공정 중 말기구간의 특징인자와 가공조건 변수간의 관계를 재정립하고자 한다. 정립된 신경망의 모델을 기반으로 가공조건에 따른 가공물의 품질예측 성능을 평가한다.




Fig. 1 Process schematics⁽⁹⁾

2. 이론적 배경

2.1 모델링

디스크상의 변형을 고려한 유연디스크 연삭가공 2차원 모델은 공작물과 공구의 동력학 및 기하학적인 관계에 의거 개발되었다. 디스크의 변형율은 공정변수와 함께 다음과 같은 비선형식으로 정의된다(Fig. 1)⁽⁶⁾.

$$\dot{\alpha} = -\frac{v_{fx} \sin\alpha}{R_{sm}} + \frac{1}{\text{area } R_{sm}} [k_1 \omega \mu K_s (\alpha_0 - \alpha) \frac{R_s}{R_{sm}} - k_2] \quad (1)$$

접촉길이와 공작물폭으로 정의되는 $\text{area}(A \times b)$ 및 R_{sm} 은 가공 단계에 따른 기하학적인 인자화 함께 정의된다. 주요변수들로서 공작물의 이송속도(v_{fx}), 초기절삭깊이(d_{oc_0}), 절삭속도(w), 디스크 각속도($\dot{\alpha}$), 디스크의 변형속도(v_n)가 있다.

이러한 관계식에 따라 수치해석에 의하여 정의되는 가공물의 형상은 초기, 중기 및 말기 또는 종료단계로 구분된다(Fig. 2). 평면구간인 중기단계를 제외한 초기와 말기단계는 가공물의 품질을 저하시키지만 이를 잘 활용하면 가공물에 챔퍼링(chamfering)으로 모서리부를 완화시키는 디버링작업에 이용할 수 있다.

공정의 특징점 P_i 는 가공단계에 따라 다음과 같이 정의한다⁽¹¹⁾.




Fig. 2 Process stages

- $P1(P1_x, P1_y)$: 가공면 생성시작점(중기단계 시작점)
- $P2(P2_x, P2_y)$: 평면구간 시작점
- $P3(P3_x, P3_y)$: 평면구간 종료점(중기단계 종료점)
- $P4(P4_x, P4_y)$: 작업종료점

가공물의 특성인 종료단계의 특징을 분석하기 위하여 종료구간비, R_{es} 와 종료구간 챔퍼링각(챔퍼링각), α_{es} 를 다음과 같이 정의한다.

$$R_{es} = \frac{P4_x - P3_x}{L} = \frac{P4_x - P3_x}{P4_x - P1_x} \quad (2)$$

$$\alpha_{es} = \left| \tan^{-1} \left(\frac{P4_y - P3_y}{P4_x - P3_x} \right) \right| \quad (3)$$

단 L 은 공작물의 길이이다.

2.2 인공지능 신경망

신경망은 변수간의 관계가 해석적으로 정의되지 않은 경우에 인과관계를 유추하기 위하여 사용되며 공학, 금융, 의학분야 등 다양한 분야에서 사용되고 있다. 입력인자와 목표인자를 나타내는 입력과 출력층 및 은닉층으로 정의되는 다층구조를 사용하며 층간에 전달특성을 관장하는 시그모이드(Sigmoid)함수를 사용하였다. 신경망의 학습을 위하여 시뮬레이션을 통한 시험자료를 생성하며 이를 오류역전파 알고리즘(Backpropagation algorithm)을 적용시켜 신경망

Table 1 Process condition range

Parameter	w (rpm)	v_{fx} (mm/sec)	d_{oc0} (mm)	L (mm)
Range	Min	1500.0	3.0	50.0
	Max	3500.0	0.5	100.0
Increment	500.0	5.0	1.0	10.0
Variations	5	5	6	6

의 특성인자인 가중치를 결정하였다⁽¹²⁾. 프로그램은 그 효용성이 검증된 Matlab사의 신경망(Neural network) 툴박스(Toolbox)를 사용하였다.

3. 결과 및 고찰

3.1 가공특성

유연디스크 가공시스템의 종료단계 특성을 분석하기 위하여 이송속도, 절삭깊이, 절삭속도 및 공작물의 길이의 절삭조건을 다양한 경우에 대하여 분석하였다. 분석에 사용한 가공인자와 범위, 조합 가짓수는 Table 1과 같다.

유연디스크 가공시스템의 특성인자인 종료구간비 R_{es} 및 종료구간 챔퍼링각 α_{es} 의 성향을 분석하였다. 종료구간의 형상특징을 정의한 챔퍼링각은 Fig. 2에서와 같이 종료구간내에서도 선정지점에 따라 변화하지만 특징적인 값을 추출하기 위하여 구간 전체의 평균변화율을 나타내는 기울기각을 적용하였다.

종료구간의 비 R_{es} 및 종료구간 챔퍼링각 α_{es} 의 성향을 공작물길이, 절삭속도, 이송속도 및 절삭깊이 변화에 대하여 분석하였다. 공작물의 길이가 증가할 경우 종료구간비는 감소하였으나 챔퍼링각의 변화는 없었으며 절삭속도 w 가 증가함에 따라 종료구간비는 증가하였으나 챔퍼링각은 감소하였다(Figs. 3, 4).

이송속도 증가에 따라 종료구간비는 감소하였으나 종료구간 챔퍼링각은 증가하였다. 이송속도가 일정한 경우 공작물길이 증가에 따라 종료구간비는 감소하였으나 종료구간 챔퍼링각은 일정하였다(Figs. 5, 6).

절삭깊이 증가에 따른 종료구간비 및 종료구간 챔퍼링각은 증가하였다(Figs. 7, 8). 일정한 절삭깊이에 대하여 공작물길이가 증가함에 따라 종료구간비는 감소하였으나 챔퍼링각은 일정하였다.

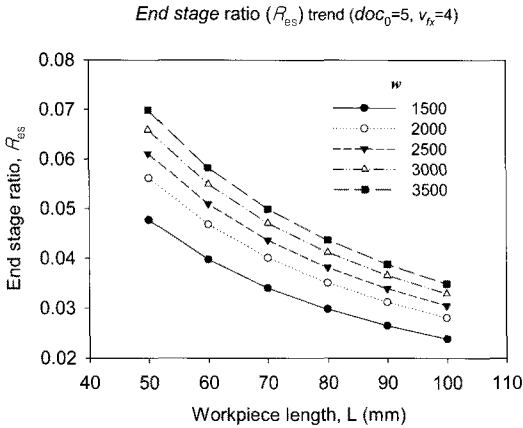


Fig. 3 R_{es} trend for various w

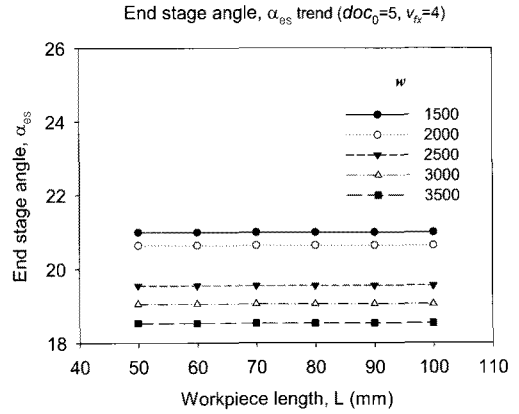


Fig. 4 α_{es} trend for various w




Fig. 5 R_{es} trend for various v_{fx}

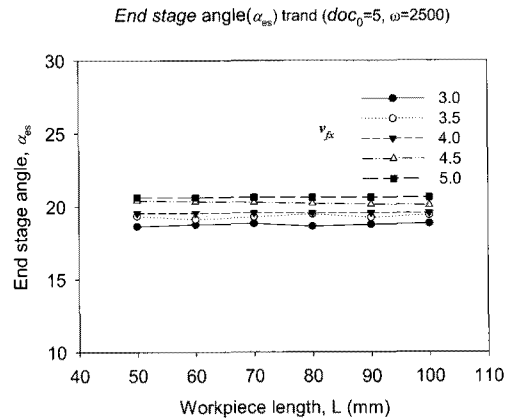


Fig. 6 α_{es} trend for various v_{fx}

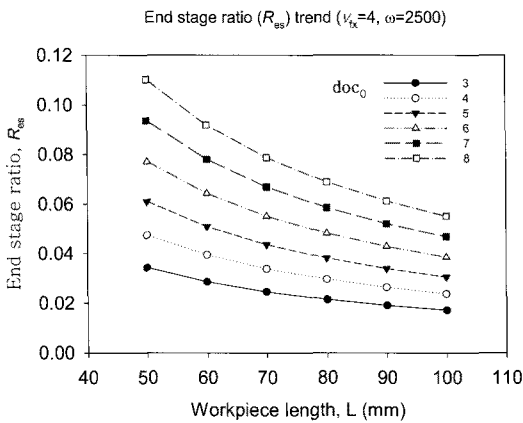


Fig. 7 R_{es} trend for various doc_0

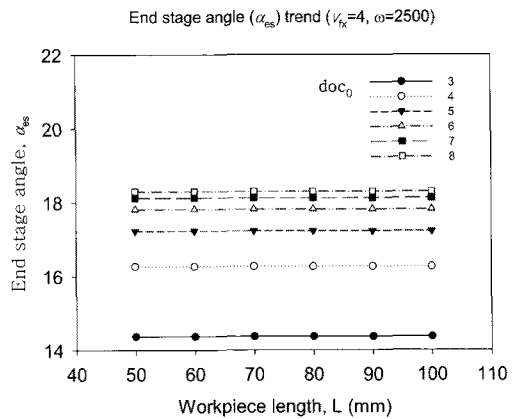


Fig. 8 α_{es} trend for various doc_0

3.2 가공 특성 예측

인공지능 신경망을 적용시켜 종료구간의 형상에 대한 공작물의 가공특성인 R_{fs} 와 α_{es} 를 예측한다. 적용되는 조건의 조합에 대한 신경망의 성능을 판단하기 위한 단계로서 3가지의 가공조건을 변화적용시킨 경우와 공작물의 길이를 추가한 4가지의 가공조건을 변화시켜 적용한 경우에 대한 성능평가를 비교하였다.

3.2.1 3가지 가공조건 적용 예측

3가지의 가공조건에 대한 출력인자 1가지인 R_{fs} 또는 α_{es} 을 각각 예측하는 경우와 2가지를 모두 예측하는 경우에 대한 비교 평가를 하였다. 이러한 조합에 대한 가공조건의 적용기준은 Table 2와 같다⁽¹¹⁾. 즉 절삭속도, 이송속도 및 절삭깊이를 각각 9, 5, 6가지로 조합하여 총 270개의 자료를 생성하였으며 그 중 240개는 학습자료로 나머지 30개는 신경

Table 2 Neural network condition⁽¹¹⁾

Parameter		w (rpm)	v_{fx} (mm/sec)	doc_0 (mm)
Range	Min	1500.0	3.0	3.0
	Max	3500.0	5.0	8.0
Increment		250.0	0.5	1.0
Variations		9	5	6

Table 3 Error rate in predicting either R_{fs} or α_{es}

Hidden layer nodes	Prediction error rate (%)	
	R_{fs}	α_{es}
10	3.2	1.7
11	3.5	1.3
12	3.0	1.7
13	5.2	1.6
14	3.2	1.6
15	3.2	1.7
16	3.1	2.1
17	2.9	1.7
18	3.3	2.5
19	3.1	1.6
20	3.4	2.0

망의 결과를 예측하는 자료로 활용하였다. 자료를 정규화(Normalization)를 거쳐 활용하였다. 신경망은 단일층 구조이며 입력, 은의 및 출력층의 인자수가 각각 3, N, 1이다. 은의층의 인자수에 따른 성능평가비교를 위하여 노드(Node)를 10에서 20까지 변화시켜 비교하였다. 성능평가지수는 동일한 조합에 대한 10번 적용을 결과에 대한 평균예측오차율을 이용하였다.

Table 3에서 종료구간비에 대한 오차율이 최저 2.9% 최대 5.2%로 종료구간 챔퍼링각에 대한 오차율인 최저 1.3% 최대 2.1% 보다 높게 나타났다. 최저오차율, 즉 최고의 예측율을 기대할 수 있는 은의층 노드수는 관찰할 수 없었다. 예측률은 일부 노드수가 많은 경우에 예측오차율이 낮게 나타났으나 일반적인 성향을 아닌 것으로 나타났다. Fig. 9는 종료구간비 예측시 은의층 노드 10개에 대한 비교이며 Table 3에서 3.2%의 오차율에 대한 예측을 도식한 것이다.

종료구간비 및 종료구간 챔퍼링각 모두를 예측하는 신경망의 구조는 입력인자 3개, 은의층 인자 N개 그리고 출력노드수 2개이며 이때 구조는 $3 \times N \times 2$ 이다. 학습은 단일 출력을 예측할 경우와 같은 자료를 사용하였다. 중간층 인자수를 10에서 20개까지 변화시킨 결과에 대한 평균예측오차율을 나타내었다(Table 4). 종료구간비 및 종료구간 챔퍼링각을 동시에 예측할 경우에 오차율은 최저 2.0%에서 최대 2.6%로 나타났다. 3가지의 가공조건을 입력인자로 사용하는 경우 R_{fs} 및 α_{es} 를 동시에 예측하는 경우에 대한 오차는 α_{es} 를 예측하는 경우보다는 높고 R_{fs} 를 예측하는 것보다는 비교적 낮은 것으로 나타났다(Fig. 10).




Fig. 9 Target vs prediction

Table 4 Error rate in predicting both $R_{e,s}$ and $\alpha_{e,s}$

Hidden layer nodes	Prediction error rate(%)
10	2.5
11	2.4
12	2.2
13	2.6
14	2.5
15	2.3
16	2.4
17	2.4
18	2.3
19	2.0
20	2.3

Table 5 Neural network process condition

Parameter	w (rpm)	v_{fx} (mm/sec)	doc_0 (mm)	L (mm)
Range	Min	1500.0	3.0	50.0
	Max	3500.0	5.0	100.0
Increment	500.0	1.0	1.0	10.0
Variations	5	3	4	6

Table 6 Error rate in predicting either $R_{e,s}$ or $\alpha_{e,s}$

Hidden layer nodes	Prediction error rate(%)	
	$R_{e,s}$	$\alpha_{e,s}$
10	3.6	3.5
11	3.4	3.3
12	3.6	3.3
13	4.0	3.6
14	3.7	2.9
15	3.6	3.1
16	3.6	3.0
17	3.9	2.9
18	3.9	3.2
19	4.4	3.3
20	3.6	2.7

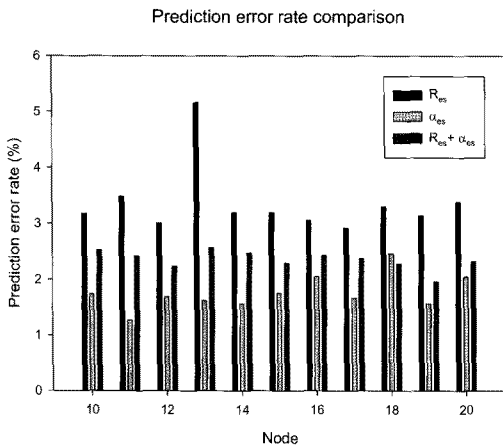


Fig. 10 Prediction error rate comparison

3.2.2 4가지 가공조건 적용 예측

가공조건 3가지와 공작물의 길이 L 을 동시에 신경망에 적용시키는 경우에 대한 예측율을 평가한다. 적용조건은 Table 3에 추가되는 공작물의 길이를 고려한 것으로 Table 4와 같다. 가공조건인 절삭속도, 이송속도, 절삭깊이와 공작물길이는 각각 5, 3, 4 및 6가지로 변화시켜 총 360가지의 경우를 생성하였다. 구축된 자료 중 330개는 신경망을 학습시키는 데 사용하고 나머지 30개는 신경망의 성능을 평가하는 자료로 활용하였다. 입력자료의 수가 4개이므로 변화하는 은닉층의 노드수를 고려하여 $4 \times N \times 1$ 의 구조를 적용하였다. 은닉층의 노드수 변화에 대한 $R_{e,s}$ 및 $\alpha_{e,s}$ 각각의 예측

율은 Table 6과 같다. 종료구간비는 3.4%에서 4.4%의 오차 범위를 보였으며 종료구간 챔퍼링각은 2.7%에서 3.6%로 약간 더 우수한 결과를 나타냈다.

종료구간비 및 종료구간 챔퍼링각 $R_{e,s}$ 및 $\alpha_{e,s}$ 를 동시에 예측하는 신경망은 입력, 은닉 및 출력층의 인자수가 각각 4, N , 2로서 $4 \times N \times 2$ 의 구조를 지닌다. 학습 및 평가를 위한 자료의 배분은 전질의 조합과 같이 각각 330 및 30개이다. 은닉층의 노드수 변화에 대한 결과인 Table 7에 의하면 2가지를 모두 예측하는 경우 오차율의 범위가 3.1%에서 3.9%로 나타났다.

4개의 입력인자를 사용한 예측율 성능평가 결과 3가지를 사용한 경우와 마찬가지로 $R_{e,s}$ 및 $\alpha_{e,s}$ 를 동시에 예측하는 것이 $R_{e,s}$ 를 예측하는 경우보다는 우수하나 $\alpha_{e,s}$ 예측보다는 낮은 것으로 나타났다(Fig. 11).

유연디스크 가공물의 품질평가와 관련하여 신경망에 입력인자를 추가로 적용시키는 것의 우수성여부를 판별하고자

Table 7 Error rate in predicting both $R_{e,s}$ and $\alpha_{e,s}$

Hidden layer nodes	Prediction error rate (%)
10	3.4
11	3.2
12	3.6
13	3.3
14	3.3
15	3.7
16	3.1
17	3.7
18	3.3
19	3.5
20	3.9

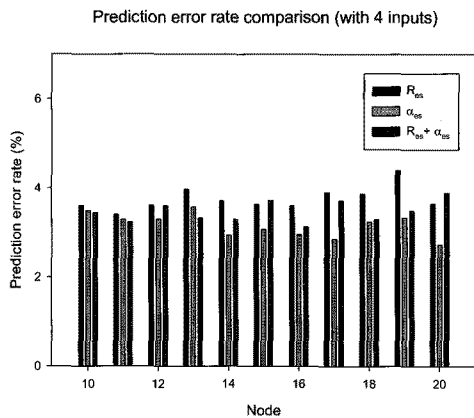


Fig. 11 Prediction error rate comparison

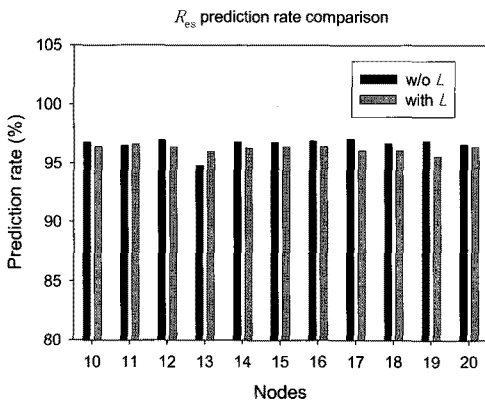


Fig. 12 $R_{e,s}$ prediction rate comparison




Fig. 13 $\alpha_{e,s}$ prediction rate comparison

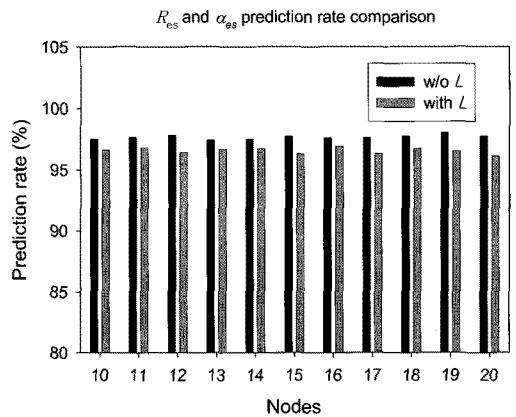


Fig. 14 $R_{e,s}$ and $\alpha_{e,s}$ prediction rate comparison

3가지와 4가지의 입력인자수에 대한 결과를 비교하였다. 공작물의 길이를 부가하여 입력인자를 증가시켜 적용시킨 결과에 4가지의 경우에 예측율이 낮은 것으로 나타났다(Figs. 12~14).

4. 결론

본 연구에서는 유연디스크 연삭가공의 가공결과인 공작물의 형상 중 종료구간의 특성을 분석하고 인공지능 신경망을 적용시켜 다음과 같은 결론을 도출하였다.

- (1) 절삭깊이, 절삭속도가 증가하거나 이송속도가 감소하는 경우에 종료구간비가 증가하였고 절삭깊이, 이송속도가

증가하거나 절삭속도가 감소하는 경우에 종료구간 챔퍼링각이 증가하였다.

- (2) 챔퍼링구간의 특징을 단일 기울기로 정의하였으나 세부 구간별로 상세히 분할하여 적용시키는 경우 좀 더 상세한 공정계획을 수립하여 가공물의 품질향상에 기여할 것이다.
- (3) 신경망에 적용시킨 입력인자의 수에 대한 분석으로 공작물길이 인자를 추가하는 것은 예측을 오차를 감소시키지 못하므로 다른 입력인자를 제거하여 상대적인 중요도를 판단할 필요가 있다.

본 연구결과는 가공공정의 데이터베이스와 연동하여 최적의 가공조건을 도출과 함께 가공물의 품질향상을 위한 가공계획수립에 활용할 수 있을 것이다.

참고 문헌

- (1) Lee, J. I., Kim, T. W., Park, Y. W., and Kwak J. S., 2008, "A Study on Deburring Process for Thin Magnesium Plate", *Proc. of KSMTE Fall Conf.*, pp. 302~306.
- (2) Shin, T. H., Baek, S. Y., and Lee, E. S., 2009, "The Evaluation of Electrochemical Deburring on Cellular Phone External Frame", *Proc. of KSMTE Spring Conf.*, pp. 135~140.
- (3) Park, D. S., Choi, Y. H., and Kang, D. K., 2003, "The Deburring of the Actuator Arm of HDD for PC", *Proc. of KSMTE Spring Conf.*, pp. 155~160.
- (4) Song, M. K., Baek, J. Y., Shin, K. S., and Yoo, S. M., 2001, "Quality Measurement of Deburring Product using Image Processing", *Proc. of KSMTE Spring Conf.*, pp. 119~124.
- (5) Kurfess, T. R., 1988, "Verification of Dynamic Grinding Model", *Trans. ASME, J. of Dynamic Sys and Control*, Vol. 110, No. 4, pp. 403~409.
- (6) Yoo, S. M., Choi, M. J., and Kim Y. J., 2000, "Model Development of Flexible Disk Grinding Process", *KSME international J.*, Vol. 14, No. 10, pp. 1114~1121.
- (7) Yoo, S. M., 1996, "A Study on the Flat Surface Generation Using Flexible Disk Grinding", *J. of the KSPE*, Vol. 13, No. 7, pp.158~166.
- (8) Yoo, S. M., 2007, "A Study on the Flat Surface Zone of the Flexible Disk Grinding System", *Transaction of KSMTE*, Vol. 16, No. 6, pp. 125~132.
- (9) Kim, H. G. and Sim, J. H., 2007, "Performance Evaluation of Chip Breaker Utilizing Neural Network", *Transaction of KSMTE*, Vol. 16, No. 3, pp. 54~74.
- (10) Prasopchaichana, K. and Kwon, O. Y., 2008, "Sensor Fusion and Neural Network analysis for Drill-Wear Monitoring", *Transaction of KSMTE*, Vol. 17, No. 1, pp. 77~85.
- (11) Yoo, S. M., 2008, "A Study on the Flexible Disk Grinding Process Parameter Prediction Using Neural Network", *Transaction of KSMTE*, Vol. 17, No. 5, pp. 123~130.
- (12) Yoo, S. M., 2009, "A Study on the Flexible Disk Deburring Process Arc Zone Parameter Prediction Using Neural Network", *Transaction of KSMTE*, Vol. 18, No. 6, pp. 681~689.